

大規模な化合物データベースからの類似化合物探索手法

河村 元[†] 濑尾 茂人[†] 竹中 要一[†] 松田 秀雄[†]

大阪大学大学院情報科学研究所[†]

タンパク質、化合物データベース等を用いて創薬のための化合物探索を行う際には、複数の大規模な創薬関連データベースを探索しなければならない。しかしながら、データベースの容量が膨大であるため単純に検索すると組合せ爆発を起こす恐れがある。そこで、本研究では、複数の創薬関連データベースを用いて、ターゲットタンパク質から相互作用する化合物を、組合せ爆発を抑えながら探索する手法を提案する。具体的には、ターゲットタンパク質から相同なタンパク質集合を探査し、相互作用情報と化合物探索手法によって、相互作用する化合物を推定する。本手法を既知のタンパク質・タンパク質-化合物相互作用、化合物のデータベース群に対して評価実験を行い、有用性を示す。

キーワード 化合物、データベース、化合物探索、Random Forest, proximity measure

1. まえがき

生体内で目的とするレセプターへ特異的に結合する化合物（リガンド）を見つけるため的一般的な手法は化合物の部分構造に着目し、構造類似度を評価する探索手法である。特に疾患の目標となるタンパク質（ターゲットタンパク質）に作用するリガンド候補を探査する場合にはこのような類似構造化合物を探査する手法は非常に有用である[1]。タンパク質の作用が分かっている場合や天然の有機化合物や合成物が何らかの作用を示すことが既知の場合には化合物データベースからリガンドの候補を探し出すことが可能である[2]。この手法では、新規ターゲットタンパク質へ作用するリガンドの情報が創薬のプロセスの後半で既知でなければならない。そこで新規ターゲットタンパク質に作用するリガンド活性化合物の探索手法として、

- (1) ターゲットタンパク質から BLAST を用いて相同性検索を行う。
- (2) 相同なタンパク質に対して作用既知の化合物を見つける。
- (3) 見つけた化合物と構造が類似した化合物の探索を行う。

という複数の検索段階を持った探索手法が提案されている[3]。L₁がターゲットタンパク質T₁のリガンドであり、かつL₂はタンパク質T₂のリガンドであるとすると、T₁とT₂が相同であればL₁とL₂の活性も「類似」であると考えることができる。これらL₁とL₂は共に特有の構造を有して

A Search Method for Similar Compounds in Very Large Compound Database

Gen Kawamura[†], Shigeto Seno[†], Yoichi Takenaka[†],
Hideo Matsuda[†]

[†]Graduate School of Information Science and Technology,
Osaka University




図 1: ターゲットタンパク質からの類似構造に基づく相互作用探索

いると予想できる。このような考え方を利用して活性未知の新規ターゲットタンパク質T₁から相同性検索、相互作用検索、化合物探索を組合せてリガンドL₁を探索できる（図1）。この探索結果のリガンドL₁は新規ターゲットタンパク質T₁に作用する可能性があると考えられる。しかし、化合物を探索するために一般的に利用されているMACCSキーとTanimoto係数を利用した類似化合物の探索手法は、活性クラスに対応した部分構造の重要度を反映できないので特有の構造を持つ化合物を見落してしまう可能性がある。さらに、このようなタンパク質の相同性も考慮したリガンドの探索方式は、いくつもの探索手法を連結するため検索結果が急激に増大し大量の無関係の化合物が拾いあげられる可能性がある。特に、化合物探索ではタンパク質の相同性を反映しながら多クラスの活性を識別し精度良く化合物候補を検索する必要がある。

2. 提案手法

本研究では、図1の手法のリガンド L_2 からリガンド L_1 の化合物の探索部分へ、機械学習法のRandom Forestのproximity measure[4] [5]とTanimoto係数[1]による化合物類似尺度を線形判別分析[6]によって組合せたスコアを利用した探索法を使用する。この化合物探索手法は活性化合物のproximity measureとTanimoto係数の正誤の傾向を線形判別法で組合せてスコア化することで精度よく活性化合物の探索を行うことが出来る。本手法をタンパク質の相同性検索や相互作用検索と組合せることで活性未知のターゲットタンパク質からのリード活性化合物の探索が可能である。

3. 評価実験

評価実験のデータとしてドーパミンD2レセプター（以下、D2レセプター）の(SwissProt ID: P14416)をターゲットタンパク質として想定した。このD2レセプターに対して相同なD1レセプター(SwissProt ID: P21728), D3レセプター(SwissProt ID: P35462), D4レセプター(SwissProt ID: P21917)を考える。D2レセプターに対してBLASTで相同性検索を行った結果が表1である。この表からドーパミンD3, D4, D1レセプターの順序で相同性が高い(E-valueが小さい)ことが分かる。

表1: ドーパミンD2レセプターに対する相同性探索

タンパク質	E-value
ドーパミンD3レセプター	3E-109
ドーパミンD4レセプター	5E-56
ドーパミンD1レセプター	2E-29

図2のグラフは提案手法によってD1リガンド, D3リガンド, D4リガンドの識別器を構築し、これらリガンドをリファレンスとしてD2リガンドを含むリファレンス化合物を検索した化合物ランキング順位の結果である。上位約750位でD2リガンドがD3リガンド, D4リガンド, D1リガンドの順で選択された。これはD3レセプターがD2レセプターの相同性に対応している。D3リガンドをリファレンスとしてD2リガンドを検索した場合には、本手法ではD3として識別される化合物が多く取得できるということである。ランキングの上位の化合物を取得すればD2レセプターに相同性のある順序にしたがってD2リガンドが取得できることが分かる。このことから本手法は未知タンパク質からの活性化合物探索に有効であることが分かる。




図2: D1, D3, D4リガンドをリファレンスにしたD2リガンドのランキング

4. むすび

相同的タンパク質に対して活性既知のリガンドからの類似化合物探索に対して線形判別分析法による化合物類似度のスコア組合せによる探索法を行うことで化合物の活性の多クラス分類も容易に対応付けることができた。相同性の高いタンパク質から対応付いた既知リガンドを元にして提案した方法で活性探索を行うことで、ターゲットタンパク質に作用する化合物候補が精度良く探索できる。

さらに評価の結果から相同性の高い化合物をリファレンスにするほど目的とするタンパク質に対するリガンド候補が正確に検索できるので、あらかじめ既知リガンド数の上限値などのパラメータの調査などを行うことが必要と思われる。

謝辞

本研究は、サイエンスグリッド NAREGI プログラムおよび科学研究補助金特定領域研究「情報爆発」の成果である。

参考文献

- [1] J. Gasteiger and T. Engel. *Chemoinformatics*. WILEY-VCH, 2003.
- [2] 田沼靖一. ゲノム創薬. 化学同人, 2003.
- [3] A. Schuffenhauer, P. Floersheim, and P. Acklin. "Similarity Metrics for Ligands Reflecting the Similarity of the Target Proteins", *J. Chem. Inf. Comput. Sci.*, vol. 43, pp. 391–405, 2003.
- [4] L. Breiman. "Random forests", *Machine Learning*, vol. 45, pp. 5–32, 2001.
- [5] V. Svetnik and A. Liaw. "Random Forest: A Classification and Regression Tool for Compound Classification and QSAR Modeling", *J. Chem. Inf. Comput. Sci.*, vol. 43, pp. 1947–1958, 2003.
- [6] S. Balakrishnama and A. Ganapathiraju. *Linear Discriminant Analysis – A Brief Tutorial*, 1998.